

یک سیستم توصیه گر مبتنی بر محتوی برای پیشنهادات فروش و کوپن های تجارت الکترونیک

چکیده

شرکت های تجارت الکترونیک پاداش محور هر روزه هزاران تخفیف و کوپن را به صورت آنلاین به نمایش می گذارند. مشتریانی که برای خدمات کوپن آنلاین ثبت نام می کنند یا یک ایمیل خودکار را با تخفیفات انتخاب شده دریافت می کنند و یا این که تخفیفات خاص را در صفحه اول وب سایت شرکت انتخاب می کنند. تخفیفات آنلاین با کیفیت بالا انتخاب شده و از طریق این دو ابزار با استفاده از یک فرایند دستی که در آن گروهی از کارشناسان مسئول ارزیابی تازگی، محبوبیت محصول، تمایلات خردۀ فروش و سایر معیارهای مربوط به کسب و کار کار می کنند، تحويل می شوند. این فرایند پر هزینه و زمانبر بوده و بر طبق سلیقه و اولویت کاربران و یا سابقه خرید آنها نیست. در این مطالعه، ما یک سیستم توصیه گرمبتنی‌بر محتوی را پیشنهاد می کنیم که فرایند انتخاب کوپن را ساده‌تر کرده و توصیه را برای بهبود نرخ کلیک و در نهایت نرخ تبدیل، شخصی سازی می کند. در مقایسه با معیار مبتنی بر محبوبیت، سیستم توصیه گر مبتنی بر محتوی موجب بهبود شاخص های F از 0.21 تا 0.85 شده و نرخ کلیک برآورد شده را از 1.20 تا 7.80 درصد افزایش می دهد. سیستم آزمایشی امروزه برای آزمون A/B با مشتریان واقعی زمان بندی شده است.

مفاهیم CCS

- روش های محاسبه: طبقه بندی و درخت رگرسیون

- محاسبه کاربردی: خرید آنلاین

کلمات کلیدی: سیستم های توصیه گر، شخصی سازی، تخفیفات و کوپن های تجارت الکترونیک

1- مقدمه

سرویس های تجارت الکترونیک پاداش محور یک بخش آنلاین سریع الرشد می باشد که از طریق اهرم قیمت های تخفیف خورده از یک شبکه گسترده ای از شرکت های وابسته، تخفیف های نقدی (کش بک) به مشترکان ارائه می کند.

معمولًاً، یک مصرف کننده از وب سایت شرکت برای جست و جوی محصولات خاص، خرده فروشان و یا کلیک بر روی یکی از تخفیفات برجسته منتشر شده استفاده می‌کنند. سپس خریداران به وب سایت‌های خرده فروشان مربوطه هدایت می‌شوند. یک بازدید از وب سایت از طریق این هدایت موسوم به گردش خرید می‌باشد.

در عین حال، مشترکین ایمیل‌های روزانه خودکار را با رایج‌ترین تخفیفات دریافت می‌کنند. شکل ۱ قطعه‌ای از یک ایمیل خودکار روزانه را نشان می‌دهد که دارای یک فهرستی از تخفیفات و کوپن‌های فعلی است. محتوای وب سایت و ایمیل به طور دستی توسط کارشناسانی که بر تحویل با کیفیت‌ترین تخفیفات به مشتریان مرکز هستند سازمان دهی می‌شود.

پارک آبی+ 10 درصد بازپرداخت نقدی	فروشنده الف
فروش 48 ساعته: بیش از 50 درصد تخفیف	فروشنده ب
بیش از 65 درصد تخفیف برای آیتم‌های با قیمت عادی+ با پیک رایگان	فروشنده پ
روز آخر، 40 درصد تخفیف	فروشنده ت
روز آخر، تخفیف 40 درصد همه لباس‌های شنا، حول ساحل	فروشنده ث

شکل 1: مثالی از پیام تبلیغات از طریق ایمیل شامل تخفیفات و کوپن‌ها

این فرایند سازمان دهی تبلیغات به طور دستی بسیار دشوار است و برای میلیون‌ها مشتری آنلاینی که پیشنهادات تخفیف یکسانی را صرف نظر از سابقه خرید یا جست و جوی قبلی خود دریافت می‌کنند کافی نیست. یک سیستم توصیه گر قادر به پوشش دادن اولویت‌ها و سلایق مشتریان از طریق بهینه سازی انتخاب کوپن بر اساس سابقه و تشابه میان کاربران و یا آیتم‌ها می‌باشد. با این حال، در مقایسه با سیستم‌های توصیه گر سنتی در سایر حوزه‌ها نظیر فیلم (10-6) و موسیقی (16)، تخفیفات خرید به دلایل متعددی متفاوت می‌باشند:

- کوپن‌ها آیتم‌هایی به شدت فراری هستند که تنها در یک دوره زمانی محدود اعتبار دارند و پس از تاریخ انقضا، حذف می‌شوند
- مشتریان استفاده کننده از کوپن‌ها، تحت تأثیر گردش حساب و حجم معامله بالایی قرار دارند
- جمعیت کاربران و مشتریان معمولاً بین اقلیت کاربران دائمی و اکثریت کاربران موقت متغیر

است و 4- تخفیفات آنلاین به ندرت مانند تخفیفات مربوط به حوزه فیلم و موسیقی ارزیابی و رتبه بندی می‌شوند.

در نتیجه، حوزه تخفیفات آنلاین در معرض مسئله شروع و راه اندازی سرد (4) قرار دارد که در آن تاریخچه کلیک یا جست وجو برای یک آیتم جدید کافی نیست و یا بر عکس، یک تاریخچه کافی برای یک مشترک جدید وجود ندارد. روش‌های فاکتور گیری ماتریس در برابر مسئله شروع سرد ضعیف بوده (4) و قادر به پوشش دادن برخی از ویژگی‌های ضروری برای مدل سازی اولویت‌های آیتم‌های بسیار فرار و جمعیت زیادی از مشتریان نمی‌باشد.

به همین دلیل، ما رویکرد فیلترینگ مبتنی بر محتوی (CBF) را اتخاذ کردیم که در آن از کوپن‌ها و ویژگی‌های مشتریان برای ایجاد یک مدل طبقه بندی تصادفی که احتمال پسین را برای یک کوپن انتخاب شده توسط مشتری پیش‌بینی می‌کند استفاده می‌کنیم. ما به بازخورد ضمنی کاربران متکی هستیم که به طور غیر مستقیم اولویت‌ها و سلایق کاربران را از طریق رفتاری نظیر کلیک کردن بر روی تخفیفات خاص در یک لیست رتبه بندی شده بیان می‌کند. این معمولاً یک سیگنال نویزدار در مقایسه با بازخورد صریح نظیر ارزیابی‌ها و ارائه نظرات می‌باشد با این حال با اریبی‌ها و سوگیری‌های فراوانی در تاریخچه و سابقه کلیک توسط کاربر همراه است

.(23-15)

با این حال، استفاده از اطلاعات کلیک چالش برانگیز تراست زیرا مستقیماً منعکس کننده رضایت کاربران نبوده و در عین حال علایم و نشانه‌هایی در خصوص آیتم‌های نامناسب در اختیار نمی‌گذارد (بازخورد منفی)(18) که خود از اهمیت زیادی برای ایجاد یک مدل تمایزی مؤثر برخوردار است. در این مقاله، ما به بررسی شیوه استفاده از بازخورد ضمنی نویزدار برای ایجاد مدل CFB برای توصیه‌های تخفیف و کوپن می‌پردازیم. اهداف اصلی به

شرح زیر هستند:

- ما روشی را برای ایجاد نمونه‌های منفی از داده‌های بازخورد ضمنی توصیف می‌کنیم
- ما آزمایشات گستره‌های را برای مقایسه مدل‌های یادگیری مختلف انجام می‌دهیم
- ما اثبات می‌کنیم که رویکرد ما با توجه به معیار و معیار کران بالا مؤثر است.

ما به طور رسمی به مسئله توصیه کوپن به عنوان فیلترینگ مبتنی بر محتوی (17) با بازخورد ضمنی می‌پردازیم. فرض کنید که M و n به ترتیب تعداد کاربران و کوپن‌ها باشند. برای هر تعامل خرید در ماتریس $\mathbf{Y} \in \mathbb{R}^{M \times N}$, کاربر u_i در معرض تعدادی کوپن L قرار گرفته و یک کوپن خاص c_j را انتخاب و یک بازخورد ضمنی $y_{u_i, c_j} = 1$ ، $y_{u_i, c_k} = 0$ را به ازای همه آیتم‌های دیگر در فهرست با طول L تولید می‌کند که در آن $k \neq j$ و $k = \{0, 1, \dots, L-1\}$ است. پیش‌بینی یک بار گردش خرید کاربر برای تخفیفات اینلاین نیازمند برآورد تابع $\hat{y}_{u_i, c_j} = f(u_i, c_j | \Theta)$ است که در آن \hat{y}_{u_i, c_j} امتیاز پیش‌بینی‌شده تعامل اینلاین (u_i, c_j) بوده و نشان دهنده پارامترهای مدل برای یادگیری F تابع نگاشت بین پارامترها و امتیازات پیش‌بینی شده است. یادگیری می‌تواند با استفاده از الگوریتم طبقه‌بندی یادگیری ماشینی صورت گیرد که تابع هدف نظیر زیان لجستیک یا زیان آنتروپی متقاطع (12) را بهینه سازی می‌کند.

با این حال، بررسی دقیق‌تر بازخورد ضمنی مورد استفاده برای مدل سازی $y_{u_i, c_k} = 0$ لزوماً به این معنی نیست که کاربر u_i تخفیف y_{u_i, c_k} را دوست ندارد، با این حال صرفاً نشان دهنده اولویت انتخاب در این تعاملات است. کاربر می‌تواند به لیست تخفیفات مراجعه کند و یک آیتم دیگر که متفاوت از C_j است را انتخاب کند. این موجب می‌شود تا مدل سازی پیش‌بینی چالش برانگیز تر شود زیرا بازخورد ضمنی کاربر نویزدار بوده و بازخورد منفی وجود ندارد. در این رابطه، ماتنهای بازخورد مثبت را در نظر گرفته و پیش‌بینی‌های میزان خرید و بازدید را به صورت مسئله طبقه‌بندی یک طبقه (OCC) (21) مدل سازی کرده‌اند که در آن ما تنها از نمونه‌های مثبت استفاده کرده و به طور مصنوعی نمونه‌های منفی را از تاریخچه خرید کاربر استخراج (مشتق) می‌کنیم.

به منظور مدیریت فرایند طبقه‌بندی، ما دوروش یادگیری غیر پارامتری را که در برابر ویژگی‌های نویزدار انعطاف‌پذیر و در برابر داده‌های پرت مقاوم هستند و نیز قادر به مدیریت ویژگی‌های مفقود هستند (ولی لزوماً در برابر برچسب‌های نویزی مقاوم نیستند) بررسی می‌کنیم 1- جنگل‌های تصادفی (5-12، فصل 15)، 2- درخت افزایش گرادیان (9).

2-1 تولید نمونه‌های منفی

هنگام انتقاء به بازخورد ضمنی کاربر، یک شیوه پذیرفته شده این است که آیتم‌های با رتبه بالا که بر روی آن‌ها کلیک نشده است، احتمالاً از اهمیت کمتری نسبت به آیتم‌های کلیک شده دارند (20). در محیط‌های صنعتی، نه رتبه کوپن و نه فهرست کوپن ارائه شده به کاربران، قابل دسترس نمی‌باشند. در این صورت استخراج گردش‌های خرید منفی (یعنی کوپن‌های غیر مرتبط) توسط ابزارهای دیگر لازم است. برای مجموعه‌های آموزشی و آزمایشی منفی، ما روش توصیف شده در زیر را دنبال می‌کنیم

برای هر گردش خرید، ما سه مورد را استخراج کردیم: کاربر، کوپن و زمان کلیک

- تاریخچه گردش خرید کاربر بازیابی شد و همه کوپنهای کلیک شده توسط کاربر تا زمان کلیک فعلی

انتخاب گردید

- با توجه به زمان کلیک مورد نظر، همه کوپن‌های غیر منقضی در آن زمان بازیابی می‌شوند. ما این را

مجموعه داده S می‌نامیم.

- ما همه کوپن‌های کلیک شده توسط کاربر را از مجموعه کوپن‌های غیر منقضی حذف کرده و مجموعه

داده $U=S-A$ را بدست اوردهیم

- به طور یکنواخت 2-4-8 و 9 کوپن از U انتخاب شده و از هر مجموعه داده، فهرستی از گردش‌های

خرید منفی برای شبیه سازی نمونه‌های منفی در مجموعه داده ایجاد شد.

توجه کنید که ما اندازه‌های متفاوتی از مجموعه‌های منفی را برای اهداف ارزیابی نمونه برداری کردیم با این حال نتایج را برای مجموعه‌های منفی با اندازه 9 گزارش کردیم زیرا نزدیک‌ترین مقدار به شرایط سیستم واقعی است که در آن یک فهرست متشکل از 10 تخفیف به کاربر ارائه شده و او یکی از آن‌ها را انتخاب می‌کند.

2-2 جنگل‌های تصادفی

مدل‌های جنگل‌های تصادفی (5، 12، فصل 15) از فنون بسته بندی برای غلبه بر مسئله واریانس بالا و اربیبی پایین درخت تصمیم استفاده می‌کنند. یک مدل جنگل تصادفی، میانگین نتایج چندین درخت تصمیم نویزدار و نسبتاً بدون اریب آموزش دیده در بخش‌های مختلف از یک مجموعه آموزشی را محاسبه می‌کند.

روش کلی برای ایجاد مدل RF از مراحل زیرپیروی می‌کند (12، فصل 15).

به ازای $b = 1, \dots, B$ ، که در آن b تعداد کل درختان بسته بندی شده است:

-1 - نمونه را از مجموعه آموزشی استخراج کرده و یک درخت T_b را با استفاده از مراحل زیر برای هر

گروه پایانه تا زمان رسیدن به حداقل اندازه گروه n_{min} آیجاد کنید.

الف: به طور تصادفی $m \leq p$ ویژگی را از کل p ویژگی انتخاب کنید که در آن m است

ب: بهترین انشعاب گره را در میان m ویژگی انتخاب کنید

پ: گره‌های انتخاب شده را به دو گره فرزند تقسیم کنید.

-2 - درخت بدست آمده را ذخیره کنید

به منظور تعیین کیفیت تقسیم گره، شاخص‌های ناخالصی جینی یا شاخص‌های آنتروپی متقاطع را می‌توان برای

تقسیم استفاده کرد (12، فصل 9) برای فرایند طبقه‌بندی، پیش‌بینی، رأی اکثریت میان نتایج حاصل از گروه

بندی درخت است. به عبارت دیگر، اگر $\hat{C}_b(x)$ پیش‌بینی طبقه برای درخت جنگل تصادفی b_{th} باشد، سپس

طبقه‌پیش‌بینی شده $\hat{C}_{rf}^B(x) = \text{majority vote}\{\hat{C}_b(x)\}_1^B$ است.

3-2 درختان افزایش گرادیان

درخت افزایش گرادیان (GBT) (9) تابع زیان را بهینه سازی می‌کند $\mathcal{L} = E_y[L(y, F(\mathbf{x})|\mathbf{X})]$ که در آن

$F(\mathbf{x})$ به سختی قادر به مشخص کردن تابع نظری درخت تصمیم $f(\mathbf{x})$ نسبت به X می‌باشد. مقدار بهینه تابع

به صورت $F^\star(\mathbf{x}) = \sum_{m=0}^M f_m(\mathbf{x}, \mathbf{a}, \mathbf{w})$ بیان می‌شود که در آن $f_0(\mathbf{x}, \mathbf{a}, \mathbf{w})$ فرض اولیه بوده و

$\{f_m(\mathbf{x}, \mathbf{a}, \mathbf{w})\}_{m=1}^M$ به صورت صعود افزایشی بر X می‌باشد که از طریق روش بهینه سازی تعریف می‌شود.

پارامتر \mathbf{a}_m از $f_m(\mathbf{x}, \mathbf{a}, \mathbf{w})$ نشان دهنده نقاط تقسیم متغیرهای پیش‌بین بوده و \mathbf{w}_m بیانگر وزن افزایشی بر

روی گره‌های برگ درختان تصمیم متناظر با مجموعه آموزشی تقسیم شده X_j به ازای منطقه j است. برای

محاسبه $F^\star(\mathbf{x})$ ، ما بایستی به ازای هر دور افزایش m را محاسبه می‌کنیم

$$\{\mathbf{a}_m, \mathbf{w}_m\} = \arg \min_{\mathbf{a}, \mathbf{w}} \sum_{i=1}^N L(y_i, F_m(\mathbf{x}_i)) \quad (1)$$

که $F_m(\mathbf{x}) = F_{m-1}(\mathbf{x}) + f_m(\mathbf{x}, \mathbf{a}_m, \mathbf{w}_m)$ می‌باشد. این معادله نشان دهنده مرحله گرادیان نزولی

است

$$F_m(\mathbf{x}) = F_{m-1}(\mathbf{x}) + \rho_m (-g_m(\mathbf{x}_i)) \quad (2)$$

که در آن ρ_m طول مرحله و $g_m(\mathbf{x}_i)$ جهت جست وجو است. برای

حل \mathbf{a}_m و \mathbf{w}_m ، همبستگی توابع پایه $f_m(\mathbf{x}_i; \mathbf{a}, \mathbf{w}) - g_m(\mathbf{x}_i)$ را با تعیین می‌کنیم که در آن گرادیان‌ها

نسبت به توزیع داده‌های آموزشی تعریف می‌شوند. به ویژه با استفاده از بسط سری تیلور، می‌توانیم راه

حل‌های فرم بسته را برای \mathbf{a}_m و \mathbf{w}_m بدست بیاوریم. می‌توان نشان داد که

$$\mathbf{a}_m = \arg \min_{\mathbf{a}} \sum_{i=1}^N (-g_m(\mathbf{x}_i) - \rho_m f_m(\mathbf{x}_i; \mathbf{a}, \mathbf{w}_m))^2 \quad (3)$$

و

$$\rho_m = \arg \min_{\rho} \sum_{i=1}^N L(y_i, F_{m-1}(\mathbf{x}_i) + \rho f_m(\mathbf{x}_i; \mathbf{a}_m, \mathbf{w}_m)) \quad (4)$$

که می‌دهد

$$F_m(\mathbf{x}) = F_{m-1}(\mathbf{x}) + \rho_m f_m(\mathbf{x}, \mathbf{a}_m, \mathbf{w}_m) \quad (5)$$

هر دور افزایش گرادیان، اوزان \mathbf{w}_m را بر روی برگ‌ها به روز رسانی کرده و به ایجاد یک درخت جدید در

تکرار بعدی کمک می‌کند. انتخاب بهینه پارامترهای درخت تصمیم بر اساس بهینه سازی $f_m(\mathbf{x}, \mathbf{a}, \mathbf{w})$ با

استفاده از زیان لجستیک است. برای GBT، هر درخت تصمیم مقاوم به عدم توازن و داده‌های پرت است

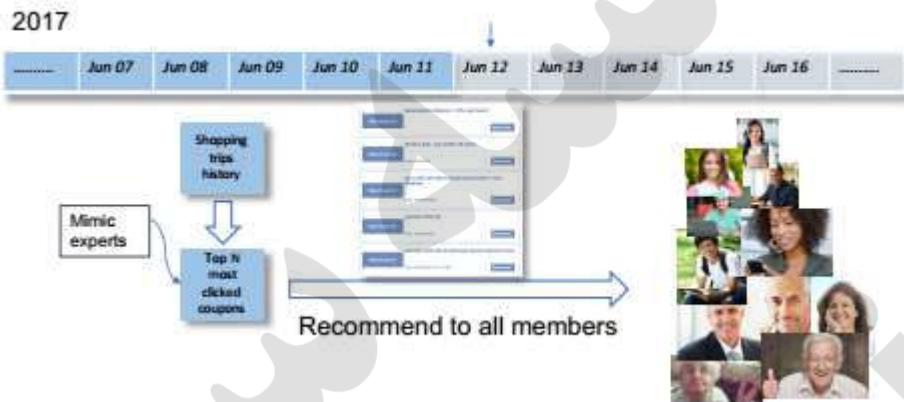
(12) و $F(\mathbf{x})$ به طور دلخواه قادر به تقریب مرزهای تصمیم پیچیده است.

4-2 معیار مبتنی بر محبوبيت

به منظور ارزیابی کارکردهای سیستم توصیه گر کوپن، ایجاد یک شاخص معیار که با عملکرد سیستم توصیه

گر فعلی همبستگی داشته باشد لازم است. با این حال، فرایند توصیه کوپن فعلی رانمی توان به طور آفلاین

ارزیابی کرد زیرا توصیه‌ها از طریق انتخاب دستی خرده فروشان و تخفیفات رایج و محبوب انجام می‌شود. فهرست کوپن‌ها از طریق ایمیل روزانه و یا بازدیدهای صفحه اول وب سایت در اختیار همه کاربران قرار می‌گیرد. همه کاربران، فهرست یکسانی از کوپن‌ها را صرف نظر از سابقه خرید یا اولویت مشاهده می‌کنند. مقایسه مستقیم با این سیستم نیازمند انتشار هر دو روش‌های توصیه‌ای از طریق تست AB با مشتریان واقعی است.



شکل 2: انتخاب کوپن معیار مبتنی بر محبوبیت با در نظر گرفتن همه کوپن‌های معتبر قبل از تاریخ گردش خرید (بازدید)

به عنوان یک رویکرد جایگزین، ما یک ارزیابی معیار افلاین را بر اساس کوپن‌های محبوب پیشنهاد می‌کنیم که در آن میزان محبوبیت از نرخ کلیک استخراج می‌شود. علاوه بر معیارهای محبوبیت، سایر دلایل مربوط به کسب و کار در خصوص انتخاب تخفیف در شرایط فعلی وجود دارند، با این حال برای معیار و اهداف شبیه سازی، حق انتخاب کمتری در خصوص معیارهای محبوبیت داریم.

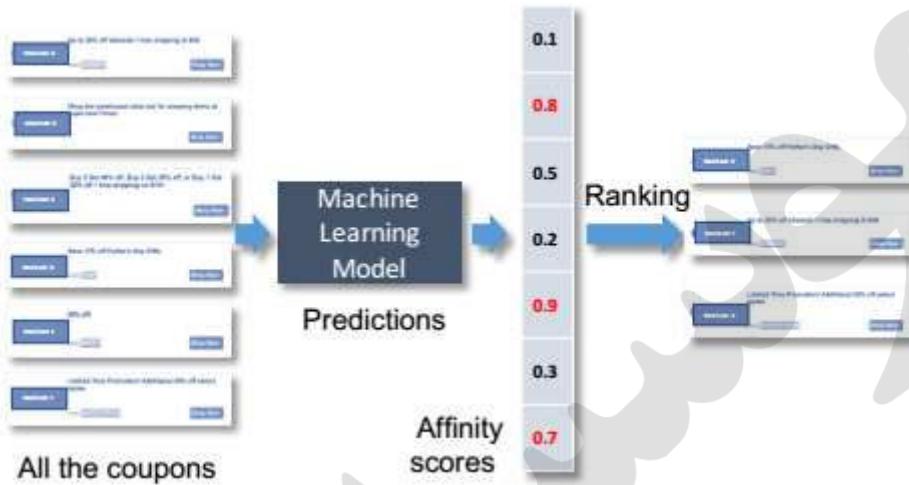
فرض بر این است که محبوبیت تعریف شده توسط کاربر با سیستم توصیه گر فعلی همبستگی دارد و احتمالاً بیانگر یک برآورده کران بالا از عملکرد است. در سطح بالاتر، دومعیار را ارائه می‌کنیم که محبوب‌ترین کوپن‌ها را براساس تنها داده‌های کلیک گذشته (PBB) و تنها بر اساس داده‌های کلیک آینده God-View (God-View PBB) که بیانگر یک کران بالاتر قوی است انتخاب می‌کند.

همان طور که در شکل 2 گفته شد، مابتدا بازدیدهای کاربران را به بخش‌های اموزشی و ازمایشی به ترتیب با نسبت 90 و 10 درصد تقسیم می‌کنیم. برای هر بازدید در مجموعه ازمایشی، ما مراحل زیرا را انجام می‌دهیم:

- ما تاریخ کلیک هر بازدید را استخراج کردیم
 - از مجموعه آموزشی، همه بازدیدهای قبل از تاریخ کلیک را با یک کوپن معتبر استخراج کردیم (یعنی کوپن‌های غیر منقضی در زمان تاریخ کلیک)
 - ما فهرستی از کوپن‌ها را بر اساس نرخ کلیک مرتب کرده و N تا از محبوب‌ترین کوپن‌ها را انتخاب کردیم
 - در صورتی که کوپن در بازدید ازمایشی در N تا از محبوب‌ترین کوپن‌ها قرار گیرد ($N=10$)، یک تطبیق وجود داشته و به این ترتیب پیش‌بینی صحیح است، در غیر این صورت پیش‌بینی غلط است
- ایده کلی این است که فهرست سفارشی با محبوبیت بالا، انتخاب کارشناس از طریق شناسایی بهترین تخفیف را برای هر یک از روزهای مورد نظر در مجموعه ازمایشی شبیه سازی می‌کند. ما هم چنین، یک معیار قوی‌تر را تعریف می‌کنیم که در آن به اطلاعات نرخ کلیک آینده پس از بازدید تحت ارزیابی دسترسی داریم. با پیش‌بینی آینده، امکان ایجادیک معیاری که کران بالای معیار مبتنی بر محبوبیت در زمان توصیه فهرست یکسانی از تخفیفات به کل جمعیت کاربر می‌باشد وجود دارد. ما این معیار را *God-View PBB (GVPBB)* می‌نامیم.

2-5 زمان اجرا

شکل 3 معماری ساده شده سیستم زمان اجرا نشان می‌دهد. لیستی از هزاران کوپن به سیستم توصیه گر ارسال می‌شود. برای هر عضو شرکت تجارت الکترونیک پاداش محور، هر جفت عضو/ تخفیف توسط سیستم توصیه گر ارزیابی شده و از نظر تشابه ارزیابی می‌شود. فهرست امتیاز حاصله برای رتبه بندی پیش‌بینی‌ها استفاده شده و سپس به 10 مورد برتر محدود شده و به صورت تبلیغات ایمیل شخصی و یا تخفیفات صفحه اول شخصی سازی شده استفاده می‌گردد.



مدل یادگیری ماشینی، پیش بینی، رتبه بندی، امتیازات وابستگی، همه کوپن‌ها

شکل 3: انتخاب و رتبه بندی کوپن‌های زمان اجرا

-3 داده‌ها

ما از داده‌های جمع آوری شده از مشتریانی که مستقیماً بر روی تخفیفات منتشر شده کلیک کرده، و یا خرید الکترونیکی را در وب سایت‌های فروشنده انجام داده بودند و در نتیجه افزودن تخفیفات یا تخفیفات خودکار از طریق افزونه‌های دکمه مرور گر، استفاده کردیم.

داده‌ها شامل اطلاعات تاریخی در مورد کلیک مشتریان (یعنی گردش خرید) برای بازدید از وب سایت‌های خرده فروشان وابسته می‌باشند. داده‌ها برای یک سال نمونه برداری شده و به دلیل قوانین محترمانگی، به صورت ناشناس در نظر گرفته شدند. جدول 1 خلاصه‌ای از توزیع مجموعه داده‌های مختلف از جمله اعضای فعالی که بازدید انجام می‌دهند، تعداد بازدیدها، کوپن‌های کلیک شده و خرده فروشانی که تخفیف ارائه می‌کنند ارائه کرده است.

از ویژگی‌های بارز کوپن‌ها، توصیفات متنی (برای مثال، 25 درصد تخفیف برای تی شرت های شنای مردانه، زنانه پسرانه، دخترانه، بیش از 30 درصد تخفیف سبک فروش و 50 درصد اضافی از سبک فروش نهایی) و یک بازه تاریخی است که نشان دهنده اعتبار آن‌هاست (برای مثال از 18/12/2016 تا 27/12/2016). به طور اختیاری، کوپن‌ها به سه مقوله طبقه بندی شدند 1- درصد تخفیف (تنزیل)، 2- تخفیف پولی و 3- تخفیف با پیک (ارسال) رایگان برای برندها و محصولات خاص. به علاوه، آن‌ها مستقیماً اشاره به یک محصول یا خرده

فروش خاص دارند. اطلاعات خرده فروشان شامل نام کسب و کار (برای مثال آرایشی بهداشتی استیلا) و مقوله انتخابی (برای مثال سلامت و زیبایی) می‌باشد. جزیيات مربوط به مجموعه داده‌های منفی در جدول 1 در بخش قبلی 2-1 توضیح داده شده‌اند.

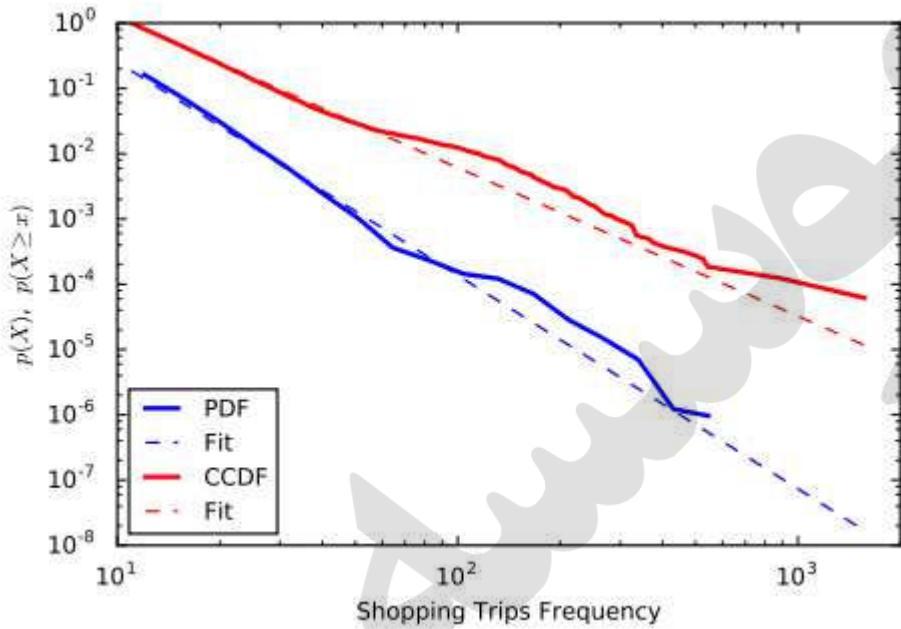
تعداد بازدیدها به ازای هر مشتری از توزیع احتمال قانون توان (1) پیروی می‌کند که در آن داده‌های دامنه سنگین دارای مقدار قابل توجهی از اطلاعات احتمال می‌باشند. شکل 4 تابع چگالی احتمال ($p(X)$) به رنگ آبی، تابع چگالی تجمعی مکمل ($p(x \geq X)$) به رنگ قرمز و برآش توزیع قانون توان متضاظر را با پارامترها $\alpha = 3.27$ و $x_{min} = 1$ نشان می‌دهد.

جدول 1: توزیع داده‌های بازدید خردید (گردش خرید) در مجموعه داده‌های متفاوت

مجموعه داده‌ها	اعضا	بازدید خرید	کوپن	خرده فروشان
آموزش	448,055	1,037,030	15,276	1,528
	49,789	114,300	7594	1,192
آزمایش	358,444	11,666,592	9,705	1,453
	39,831	1,285,875	8,190	1,413
منفی آموزشی				
منفی آزمایشی				

جدول 2: تعداد داده‌ها و آماره‌های مربوط به مجموعه‌های سر، تنہ و دم توزیع بازدیدهای خرید

مجموعه داده	اعضا	بازدیدهای خرید	درصد	حداقل	حداکثر	میانگین
سر	25,149	317,623	28.7%	8	1,569	15.79
تنہ	132,337	441,533	39.8%	3	7	4.17
دم	333,686	349,262	31.5%	1	2	1.31



فراوانی بازدید خرید

شکل 4: تابع چگالی احتمال ($p(x)$ آبی) و تابع چگالی تجمعی مکمل ($p(X \geq x)$ قرمز) با برآورد توزیع توان

$$\alpha = 3.27 \quad x_{min} = 1$$

بر اساس فراوانی (تعداد) بازدیدهای خرید (به جدول 2 مراجعه کنید)، داده‌ها را به سه بخش تقسیم کردیم. 1- سر که شامل فعال‌ترین اعضاء با بیش از 8 بازدید خرید 2- تنہ که شامل اعضاء با یک نرخ کلیک بین 2 و 7 است و 3- دم، برای افراد با کمترین فعالیت با نرخ کلیک 1 یا 2 این گونه تقسیم بندی داده‌ها در بخش 4-2 برای ارزیابی مسئله شروع سرد مبتنی بر کاربر ارائه خواهد شد.

4- آزمایشات

به منظور ایجاد و ارزیابی جنگل‌های تصادفی، XGboost، و مدل‌های معیار، داده‌ها بر اساس اعضاء با استفاده از 90 درصد جمعیت برای آموزش و 10 درصد برای آزمایش تقسیم شده و مجموعه‌های بازدیدهای خرید استخراج شد. تقسیم بندی بر اساس اعضاء به جای بازدیدهای موجب افزایش شانس پوشش دادن قابلیت‌های تعمیم مدل می‌شود زیرا تاریخچه بازدید خرید کاربران آزمایشی موجب اریبی در داده‌های آموزشی نمی‌شود. برای نمونه‌های منفی، که در بخش 1-2 گفته شد، ما 9 بازدید خرید منفی را برای هر نمونه مثبت انتخاب می‌کنیم.

برای پوشش دادن وابستگی کاربران / کوپن‌ها، تعدادی از ویژگی‌ها نظیر ویژگی‌های کوپن و کاربران و نیز ویژگی‌های تاریخچه خرید را از مایش کردیم. خلاصه‌ای از آن‌ها در زیر آمده است

- ویژگی‌های مبتنی بر کاربر

1- دستگاه‌های مورد استفاده

2- سیستم OS

3- دامنه ایمیل

- ویژگی‌های مبتنی بر کوپن

1- توصیف متن

2- خرده فروش اصلی

3- مقوله خرده فروش

4- اطلاعات تخفیف (ارسال رایگان، تخفیف دلار، تخفیف درصد)

5- اطلاعات کش بک

- ویژگی‌های مبتنی بر تاریخچه و سابقه بازدید خرید

1- تعداد دفعات قبلی بازدید کاربر از این کوپن

2- خرده فروشانی که اخیراً بازدید شده‌اند

3- اطلاعات اخیر مربوط به تخفیف

4- اطلاعات اخیر مربوط به کش بک یا تخفیف نقدی

5- کلمات کلیدی اخیر مربوط به کوپن (از توصیفات)

6- مقوله‌های خرده فروش

7- خریدهای لوکس اخیر

در مرحله پیش پردازش داده‌ها، ما متن را بر اساس فراوانی کلمات کلیدی و سابقه رفتار خرید اعضا رمز گذاری کرده و ویژگی‌های مقوله‌ای را به صورت مدل بردار و ان هات دسته بندی کردیم. همه ویژگی‌های دیگر یابه صورت مقادیر دودویی یا مقادیر عددی در نظر گرفته می‌شوند. چون هر دوی مدل‌های RF و XGBoost به

تبديل ويزگي هاي يکنواخت غير حساس است، ما از استاندارد سازی و نرمال سازی عددی اجتناب کردیم. ما به طور دقیق نرمال سازی اطلاعات مفقود را مدیریت کرده و متن مفقود را با برجسب unk و هر دو ويزگي هاي مقوله‌اي و عددی را با 0s جایگزين کردیم. پس از پیش پردازش، بهینه سازی جست و جوی شبکه جزیی برای مجموعه‌اي از ابر پارامترهای مهم، عمیق حداقل درخت و تعداد تخمین گرها به ترتیب تا 15 و 1000 اجرا کردیم. ما از پیاده تخمین گر scikit-learn (19) از درخت جنگل تصادفی و XGboost استفاده کردیم.

1-4 نتایج

جدول 3 نتایج آزمایشی را برای مدل‌های یادگیری ماشینی و معیارها نشان می‌دهد. ما عملکرد را با محدود کردن فهرست پیش‌بینی رتبه‌بندی شده به 10 آیتم ارزیابی کردیم. مدل RFC قادر به پیش‌بینی نرخ کلیک برای 96.80 درصد کوپن‌های تست شده (صحت) می‌باشد، در حالی که XGboost با پیش‌بینی کلیک صحیح 95.85 درصد و درصد فراخوانی 0.83 درصد برخوردار است. این موجب می‌شود تا نرخ کلیک پیش‌بینی شده برای XGboost با 8.30 درصد باشد. هر دوی PBB و GVPBB از فراخو. اني پاين رنج می‌برد زيرا لیست‌های محبوب برای همه کاربران يكسان هستند.

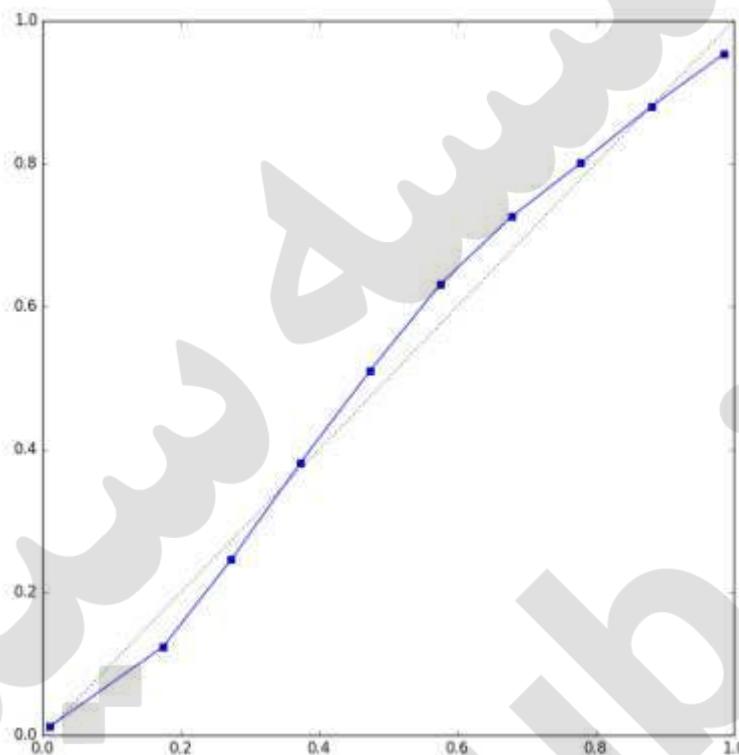
جدول 3: دقت (P)، فراخوانی (R)، شاخص F و نرخ کلیک برای طبقه‌بندی جنگل تصادفی (RFC)، XGboost، معیار مبتنی بر محبوبیت (PBB) و GVPBB با حداقل ده کوپن. روش‌های معیار با (*) نشان داده شده‌اند.

Model	P	R	F	NDCG@10	CTR
PBB*	0.91	0.12	0.21	0.776	1.20%
GVPBB*	0.83	0.34	0.48	0.892	3.40%
XGBoost	0.77	0.83	0.80	0.857	8.30%
RFC	0.93	0.78	0.85	0.969	7.80%

به طور کلی، هر دوی XGboost و RFC عملکرد بهتری از ماتریس‌های معیار نشان دادند. علاوه بر دقت، فراخوانی و F، ما متريک بهره تجمعي تنزيل يافته نرمال (14) را برای فهرستی از 10 تخفيف ايجاد شده با ترکيب 1 نمونه مثبت با 9 نمونه منفي تصادفاً انتخاب شده گزارش کردیم. NDCG يک شاخص كييفيت رتبه

بندی می‌باشد که موقعیت آیتم‌های کلیک شده را در نظر می‌گیرد. به طور کلی، نمونه‌های مثبت با ایستی بالاتر از نمونه‌های منفی رتبه بندی شوند.

سپس ماقdam به ارزیابی کیفیت امتیازات برآورد شده با مدل RFC کردیم. احتمالات پیش‌بینی شده با واسنجی خوب از اهمیت زیادی در زمان استفاده از امتیازات مدل طبقه بندی برای رتبه بندی برخوردارند (18).



شکل 5: منحنی واسنجی احتمال برای مدل RFC. محور X: مقدار پیش‌بینی شده میانگین، محور Y: کسری از نمونه‌های مثبت

نمودار کالیبراسیون (واسنجی) اطمینان در شکل 5 نشان می‌دهد که مدل RFC دارای یک اریبی جزیی حول مقدار پیش‌بینی شده 0.2 و 0.6 است با این حال به طور کلی این منحنی از رفتار ایده‌آل با تقلید از خط اریب پیروی می‌کند.

2-4 ارزیابی شروع سرد مبتنی بر کاربر

وقتی که اعضای جدید به سیستم پاداش محور یا تخفیفات جدید ارائه شده توسط خرده فروشان ملحق می‌شوند، سیستم‌های توصیه گر تحت تأثیر پراکندگی داده‌های جدید قرار می‌گیرد که عملکرد پیش‌بینی را با اریبی مواجه می‌سازد (19). به منظور حل این مسئله، یک راهبرد انتخاب متفاوت برای دامنه توزیع استفاده

می شود (روش های ترکیبی) (19). با این حال، ما برای پوشش دادن اطلاعاتی که با حداقل تاریخچه بازدید خرید تعیین داده می شود، متکی به ویژگی های مبتنی بر کوپن و کاربر هستیم.

ما اقدام به ارزیابی مدل RFC با سه بخش از توزیع بازدید خرید کردیم (به بخش 3 مراجعه کنید). جدول 4 نتایج این ازمایش را نشان می دهد.

جدول 4: دقت (P)، فراخوانی، شاخص F(f)، نرخ کلیک و NDCG@10 برای مدل RFC در زمان تست کاربران در بخش های دم، تنه و سر توزیع بازدید خرید

Data set	P	R	F	NDCG@10	CTR
Head	0.95	0.77	0.85	0.980	7.70%
Torso	0.94	0.79	0.86	0.985	7.90%
Tail	0.90	0.78	0.84	0.976	7.80%

به طور میانگین، مدل RCF یک مدل کاملاً قوی در سه بخش توزیع است. هنگام تحلیل شاخص های پیش بین ویژگی های اصلی، تعداد دفعات کلیک بر روی کوپن، از اثرات پیش بینی هستند با این حال تحقیقات بیشتری برای درک بهتر اثرات متقابل ویژگی ها لازم است.

6- کارهای مرتبه

مطالعات زیادانجام شده در خصوص سیستم های توصیه گر بر بازخورد صریحی متمرکز است که در آن کاربران اولویت خود را با ارزیابی ها (نظر دهی) (22-10) بیان می کنند. اخیراً، طیف وسیعی از مطالعات انجام شده اند که از داده های بازخورد ضمنی فراوان استفاده کرده اند (13-11-3). با این حال بیشتر این کارها، مسئله را به صورت مدل فیلترینگ مشارکتی چارچوب بندی کرده اند. CF به شدت به مسئله شروع سرد حساس است و برای مدیریت آیتم های بسیار فرار نظیر کوپن ها و تخفیفات اینلاین، فرار است. به علاوه گنجاندن ویژگی هایی که خصوصیات کاربران و آیتم ها را پوشش می دهند سخت است.

سیستم توصیه گر ترکیبی در (11) نزدیک ترین سیستم به مطالعه ماست. برای حل مسئله شروع سرد، آنها از بازخورد ضمنی برای توصیه کوپن های اینلاین با تلفیق اطلاعات کاربر و ویژگی های آیتم ها استفاده می کنند. در این مطالعه، ماتریس فیلترینگ مشارکتی سنتی، از جمله کاربران و آیتم ها، با ویژگی های آیتم و کاربر و svd

غنى مى شوند. با اين وجود، سيسitem تركيبی نشان مى دهد که در آن يك كopian يا كاربر جديid وجود دارد. در هر صورت، هزاران kopin جديid در هر روز وجود دارد و آموزش مجدد اغلب غير عملی است.

مطالعه ما با رویکردهای فیلترینگ مبتنی بر محتوى نظير (2-8) متناسب است. روش‌های CBF قادر به خلاصه سازی آیتم‌ها بوده و بیانگر اثرات متقابل کاربر/آیتم با رمز گذاري سابقه بازدید خريد می‌باشد. هنگام افزودن تخفيفات جديid، هیچ گونه نيازی به آموزش مجدد نیست، اگرچه استفاده از خرده فروشان جديid نيازمند آپديت مدل برای پوشش دادن روابط وابستگی کاربر/آیتم جديid بيان شده در بازدیدهای خريد جديid است. بر عکس مدل‌های مبتنی بر CF و SVD، رویکرد مبتنی بر محتوى قادر به استفاده از فنون طبقه بندی مختلف بوده و می‌توانند با Cf ترکيب شوند.

6-نتيجه گيري

در اين مطالعه، ما يك سيسitem توصيه گر kopin را با فیلترینگ مبتنی بر محتوى توسعه داديم. ما دو معيار مبتنی بر محبوبيت را ازمایش کرديم و آن‌ها را با هر دو مدل طبقه بندی درخت افزايش گراديان و جنگل تصادفي مقایسه کرديم. برای حل مسئله طبقه بندی يك طبقه‌اي، چارچوب ما به طور خودکار نمونه‌های منفي را از بازدیدهای خريد مشتريان استخراج کرديم. نمونه‌های منفي، سناريوي انتخاب منفي را شبие سازی می‌کnim که در آن يك kopin، نسبت به ده kopin، به طور واقعی توسيط اعضا انتخاب می‌شود. در اين شرایط ازمایشي، هر دو دسته بند XGboost و جنگل‌های تصادفي بهتر از دومعيار ديگر به جز متريک NDCG10 انجام می‌شوند. در آينده، برای بهبود نتایج رتبه بندی، ما مدل‌های طبقه بندی را با توابع هزينه مبتنی بر ليست و مبتنی بر زوج توسيعه می‌دهيم. هم چنین، مامدل های خود را تحت ارزیابی‌های تست A/B با مشتريان واقعی ارزیابی و اعتبار سنجی می‌کnim.